09 | Bigtable（二）：不认识“主人”的分布式架构

2021-10-08 徐文浩

《大数据经典论文解读》 课程介绍 >

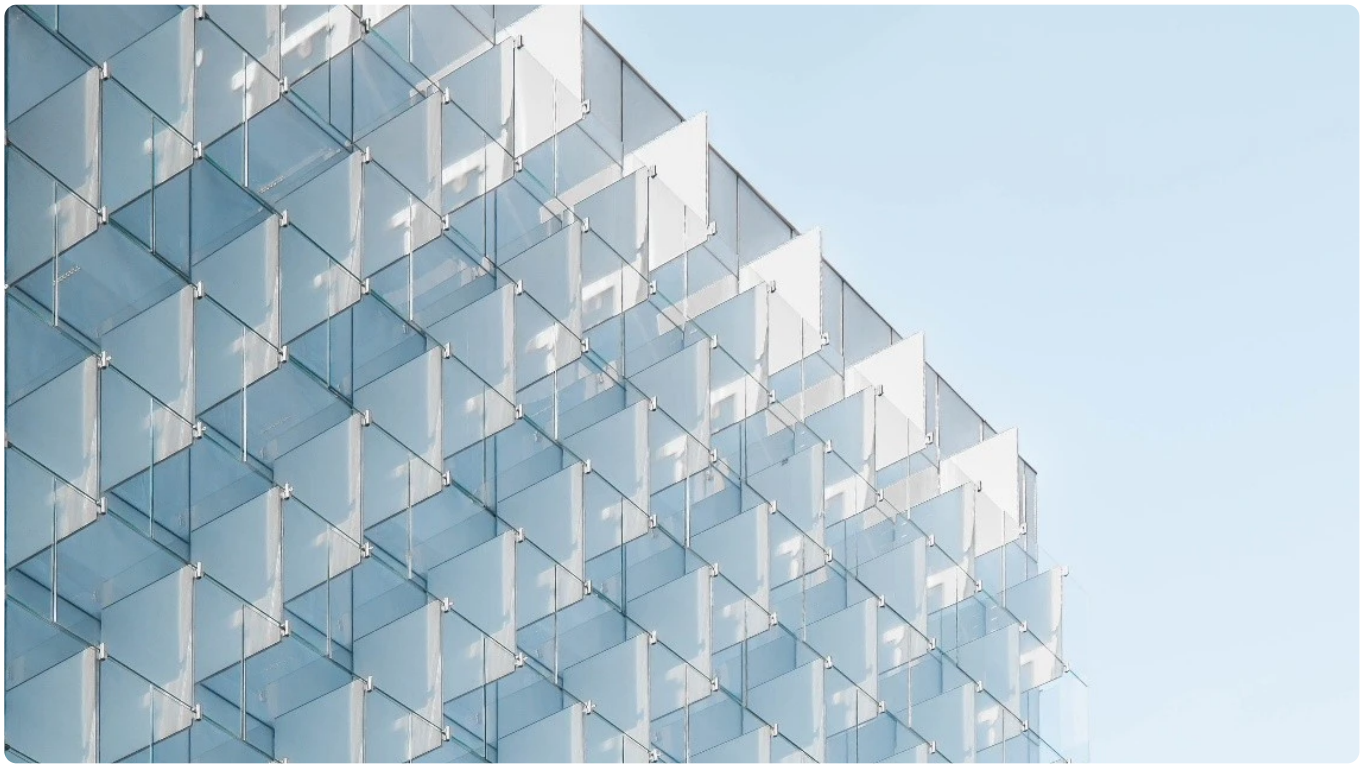

讲述：徐文浩
时长 21:34 大小 19.75M

你好，我是徐文浩。上一讲里我们一起分析了如何对一个 MySQL 集群进行扩容，来支撑更高的随机读写请求。而在扩容过程中遇到的种种不便，也让我们深入理解了 Bigtable 的设计中需要重点解决的问题。

第一个问题，自然还是如何支撑好每秒十万、乃至百万级别的随机读写请求。

第二个问题，则是如何解决好“可伸缩性”和“可运维性”的问题。在一个上千台服务器的集群上，Bigtable 怎么能够做到自动分片和灾难恢复。

今天我们就先来看看第二个问题，其实也是 Bigtable 的整体架构。而第一个问题，一半要依赖第二个问题，也就是可以不断将集群扩容到成百上千个节点。另一半，则取决于在每

一个节点上，Bigtable 的读写操作是怎么进行的，这一部分我们会放到下一讲，也就是 Bigtable 的底层存储 SSTable 究竟是怎么一回事儿。

那么接下来，我们就一起来看看 Bigtable 的整体架构。在学完这一讲后，希望你可以掌握 Bigtable 三个重要的知识点：

第一个，Bigtable 是如何进行数据分区，使得整个集群灵活可扩展的；

第二个，Bigtable 是如何设计，使得 Master 不会成为单点故障，乃至单点性能的瓶颈；

最后，自然是整个 Bigtable 的整体架构和组件由哪些东西组成。

相信在学完这一讲后，你也能自己设计一个分布式数据库的基本架构。并且，你也会对分布式数据库设计的分区和复制机制、系统整体架构设计，以及如何分析和优化整个架构的瓶颈所在，有一个清晰的了解。

理解 Bigtable 的基本数据模型

在进入到针对 Bigtable 的架构设计解读之前，我们先来弄清楚 Bigtable 基本的数据模型。

上一讲里，我们举了很多 MySQL 的例子。在这个过程中，相信你会发现，一旦我们开始分库分表了，我们就很难使用关系数据库的一系列的特性了。比如 SQL 里面的 Join 功能，或者是跨行的事务。因为这些功能在分库分表的场景下，都要涉及到多台服务器，不是说做不到，但是问题一下子就复杂了。

所以，Bigtable 在一开始，也不准备先考虑事务、Join 等高级的功能，而是**把核心放在了“可伸缩性”上**。因此，Bigtable 自己的数据模型也特别简单，是一个很宽的稀疏表。

每一张 Bigtable 的表都特别简单，每一行就是一条数据：

一条数据里面，有一个行键（Row Key），也就是这条数据的主键，Bigtable 提供了通过这个行键随机读写这条记录的接口。因为总是通过行键来读写数据，所以很多人也把这样的数据库叫做 **KV 数据库**。

每一行里的数据呢，你需要指定一些列族（Column Family），每个列族下，你不需要指定列（Column）。**每一条数据都可以有属于自己的列，每一行数据的列也可以完全不一样**，因为列不是固定的。这个所谓不是固定的，其实就是列下面没有值。因为 Bigtable 在底层存储数据的时候，每一条记录都要把列和值存下来，没有值，意味着对应的这一行就没有这个列。这也是为什么说 Bigtable 是一个“稀疏”的表。

列下面如果有值的话，可以存储多个版本，不同版本都会存上对应版本的时间戳（Timestamp），你可以指定保留最近的 N 个版本（比如 N=3，就是保留时间戳最近的三个版本），也可以指定保留某一个时间点之后的版本。

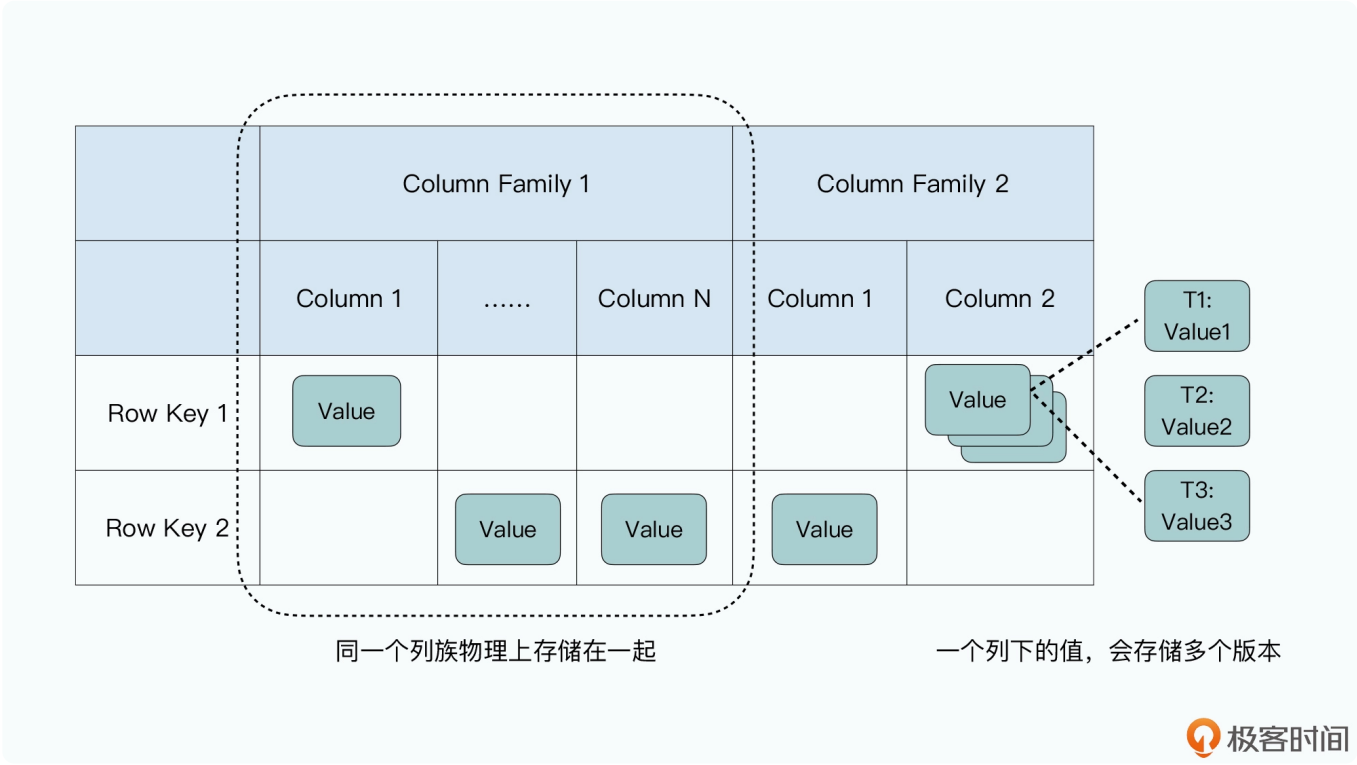

其实，这里的有些命名容易让人误解，比如列族，这个名字很容易让人误解 Bigtable 是一个基于列存储的数据库。但事实完全不是这样，我觉得**对于列族，更合理的解读是，它是一张“物理表”，同一个列族下的数据会在物理上存储在一起。而整个表，是一张“逻辑表”。**

在现实当中，Bigtable 的开源实现 HBase，就是把每一个列族的数据存储在同一个 HFile 文件里。而在 Bigtable 的论文中，Google 定义了一个叫做**本地组**（Locality Group）的概念，我们可以把多个列族放在同一个本地组中，而同一个本地组的所有列的数据，都会存储在同一个 SSTable 文件里。

这个设计，就使得我们不需要针对字段多的数据表，像 MySQL 那样，进行纵向拆表了。

Bigtable 的这个数据模型，使得我们能很容易地去增加列，而且增加列并不算是修改 Bigtable 里一张表的 Schema，而是在某些这个列需要有值的行里面，直接写入数据就好了。这里的列和值，其实是直接以 key-value 键值对的形式直接存储下来的。

这个灵活、稀疏而又宽的表，特别适合早期的互联网业务。虽然数据量很大，但是数据本身的 Schema 我们可能没有想清楚，加减字段都不需要停机或者锁表。要知道，MySQL 直到 5.5 版本，用 ALTER 命令修改表结构仍然需要将整张表锁住。并且在锁住这张表的时候，我们是不能往表里写数据的。对于一张数据量很大的表来说，这会让整张表有很长一段时间不能写入数据。

而 Bigtable 这个稀疏列的设计，就为我们带来了很大的灵活性，如同《架构整洁之道》的作者Uncle Bob说的那样：“架构师的工作不是作出决策，而是尽可能久地推迟决策，在现在不作出重大决策的情况下构建程序，以便以后有足够信息时再作出决策。”

数据分区，可伸缩的第一步

搞清楚了 Bigtable 的数据模型，我们再来一起看一看，Bigtable 是怎么解决上一讲 MySQL 集群解决不好的**水平分库问题**的。

把一个数据表，根据主键的不同，拆分到多个不同的服务器上，在分布式数据库里被称之为**数据分区**（ Paritioning ）。分区之后的每一片数据，在不同的分布式系统里有不同的名字，在 MySQL 里呢，我们一般叫做 Shard，Bigtable 里则叫做 Tablet。

上一讲里，MySQL 集群的分区之所以遇到种种困难，是因为我们通过取模函数来进行分区，也就是所谓的**哈希分区**。我们会拿一个字段哈希取模，然后划分到预先定好 N 个分片里面。这里最大的问题，在于分区需要在一开始就设计好，而不是自动随我们的数据变化动态调整的。

但是往往计划不如变化快，当我们的业务变化和计划稍有不同，就会遇到需要搬运数据或者各个分片负载不均衡的情况。你可以看一下我从上一讲里搬过来的这张图，当我们将 4 台服务器扩展到 6 台服务器的时候，哈希分区的方式使得我们要在网络上搬运整个数据库 2/3 的数据。

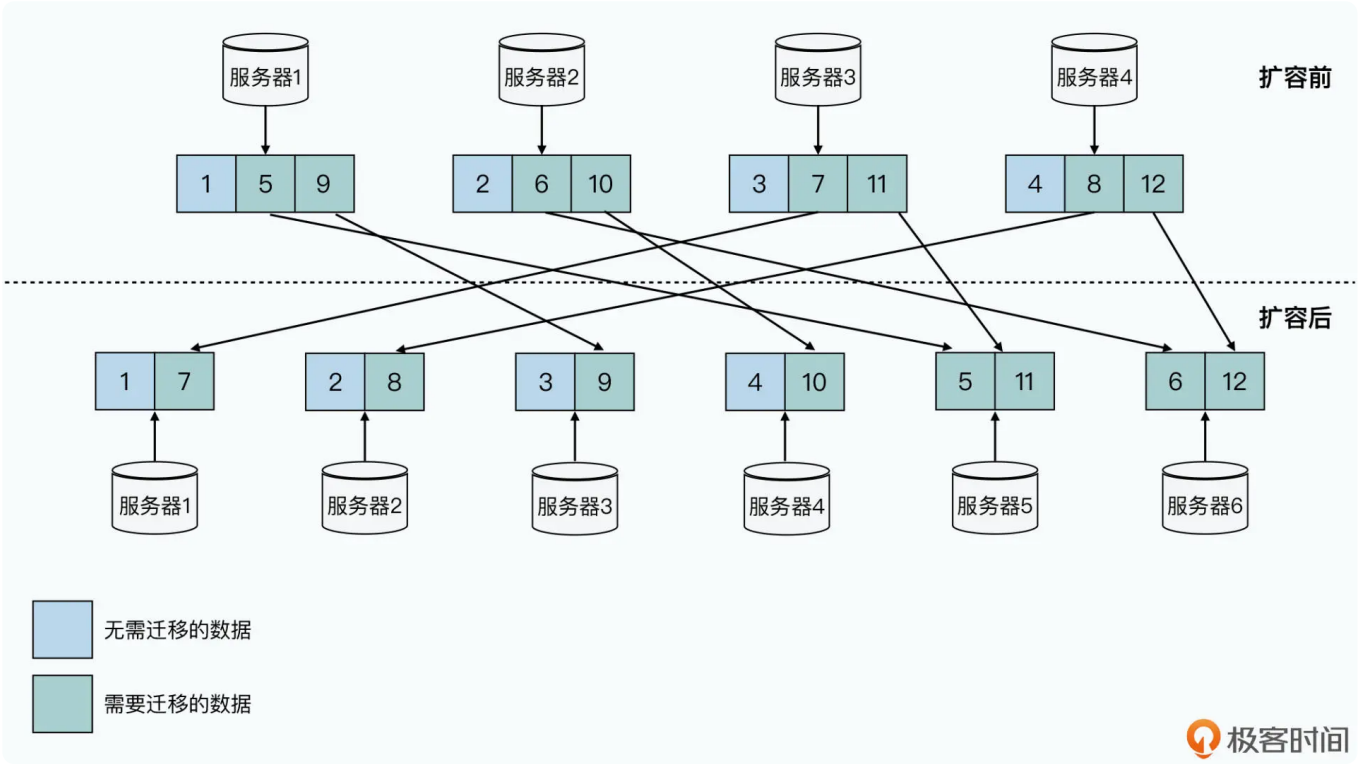

上一讲里，我们看过这个图片，哈希分区如果不是翻倍扩容，就需要搬运大量数据

所以，在 Bigtable 里，我们就采用了另外一种分区方式，也就是**动态区间分区**。我们不再是一开始就定义好需要多少个机器，应该怎么分区，而是采用了一种**自动去“分裂”（split）的方式**来动态地进行分区。

我们的整个数据表，会按照行键排好序，然后按照连续的行键一段段地分区。如果某一段行键的区间里，写的数据越来越多，占用的存储空间越来越大，那么整个系统会自动地将这个分区一分为二，变成两个分区。而如果某一个区间段的数据被删掉了很多，占用的空间越来越小了，那么我们就会自动把这个分区和它旁边的分区合并到一起。

这个分区的过程，就好像你按照 A~Z 的字母顺序去管理你的书的过程。一开始，你只有一个空箱子放在地上，然后你把你的书按照书名的拼音，从上到下放在箱子里。当有一本新书需要放进来的时候，你就按照字母顺序插在某两本书中间。而当箱子放不下的时候，你就再拿一个空箱子，放在放不下的箱子下面，然后把之前的箱子里的图书从中间一分，把下面的一半放到新箱子里。

而我们删除数据的时候，就要把书从箱子里面拿走。当两个相邻的箱子里都很空的时候，我们就可以把两个箱子里面的书放到一个箱子里面，然后把腾出来的空箱子挪走。这里的一个个“箱子”就是我们的分片，这里面的一本本书，就是我们的一行数据，而书名的拼音，就是我们的行键。可能以 A、B、C 开头的书多一些，那么它们占用的分区就会多一些，以 U、V、W 开头的书少一些，可能这些书就都在一个分区里面。

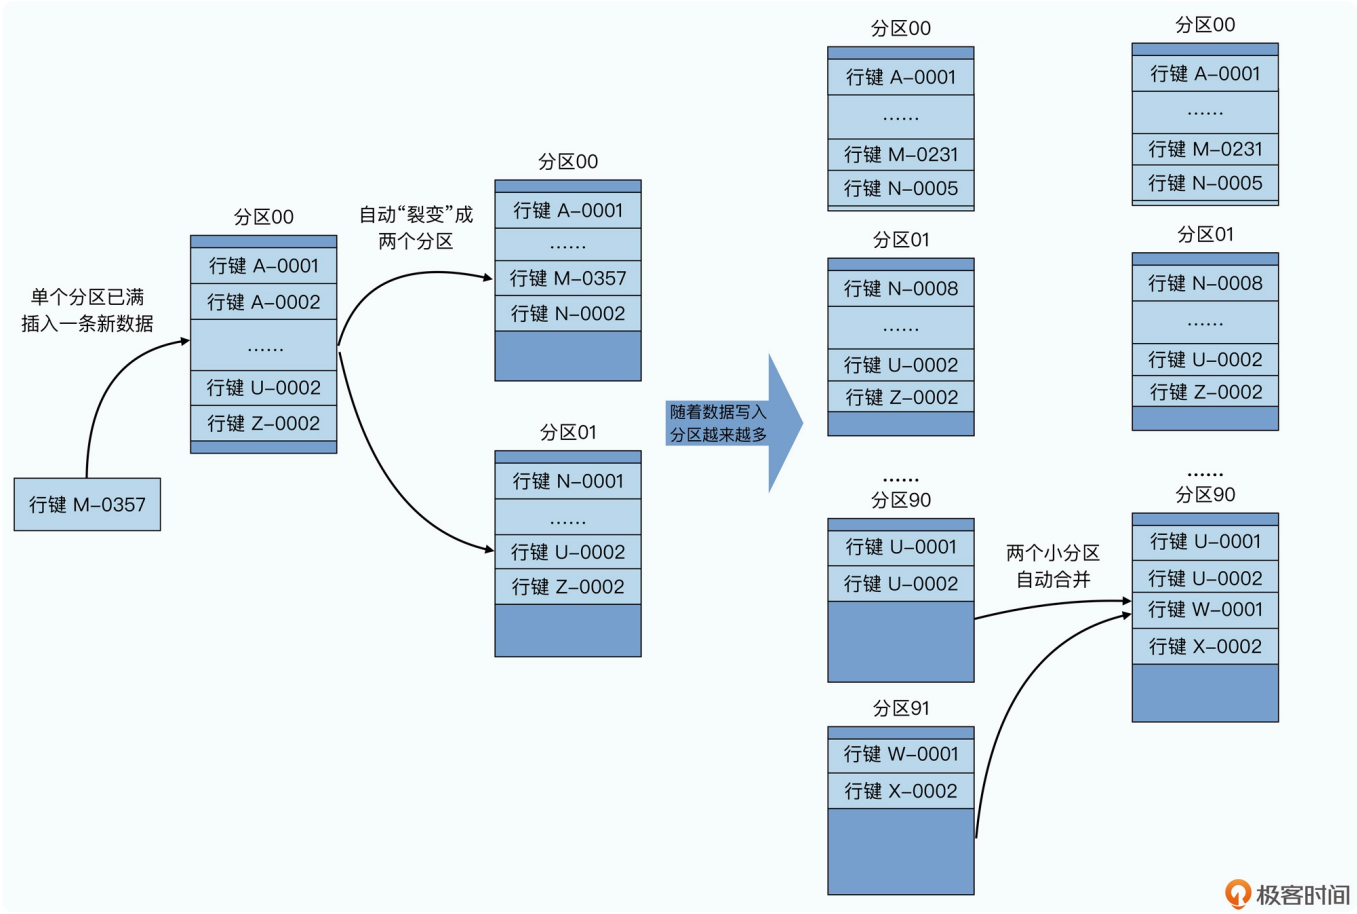

动态区间分区：自动根据当前数据分布，进行分区或者合并

采用这样的方式，你会发现，你可以动态地调整数据是如何分区的，并且每个分区在数据量上，都会相对比较均匀。而且，在分区发生变化的时候，你需要调整的只有一个分区，再没有需要大量搬运数据的压力了。

通过 Master + Chubby 进行分区管理

那么看到这儿，你可能要问了：要是上一讲的 MySQL 集群也用这样的分区方式，问题是不是就解决了？

答案当然是办不到了。因为我们还需要有一套存储、管理分区信息的机制，这在哈希分片的 MySQL 集群里是没有的。在 Bigtable 里，我们是通过 **Master 和 Chubby** 这两个组件来完成这个任务的。这两个组件，加上每个分片提供服务的 **Tablet Server**，以及实际存储数据的 **GFS**，**共同组成了整个 Bigtable 集群**。

Master、Chubby 和 Tablet Server 的用途

Tablet Server 的角色最明确，就是用来**实际提供数据读写服务**的。一个 Tablet Server 上会分配到 10 到 1000 个 Tablets，Tablet Server 就去负责这些 Tablets 的读写请求，并

且在单个 Tablet 太大的时候，对它们进行分裂。

而哪些 Tablets 分配给哪个 Tablet Server，自然是由 Master 负责的，而且 Master 可以根据每个 Tablet Server 的负载进行动态的调度，也就是 Master 还能起到**负载均衡**（load balance）的作用。而这一点，也是 MySQL 集群很难做到的。

这是因为，Bigtable 的 Tablet Server 只负责在线服务，不负责数据存储。实际的存储，是通过一种叫做 SSTable 的数据格式写入到 GFS 上的。也就是 **Bigtable 里，数据存储和在线服务的职责是完全分离的。**我们调度 Tablet 的时候，只是调度在线服务的负载，并不需要把数据也一并搬运走。

而在上一讲里的 **MySQL 集群，服务职责和数据存储是在同一个节点上的。**我们要想把负载大的节点调度到其他地方去，就意味着数据也要一并迁移走，而复制和迁移数据又会进一步加大节点的负载，很有可能造成雪崩效应。

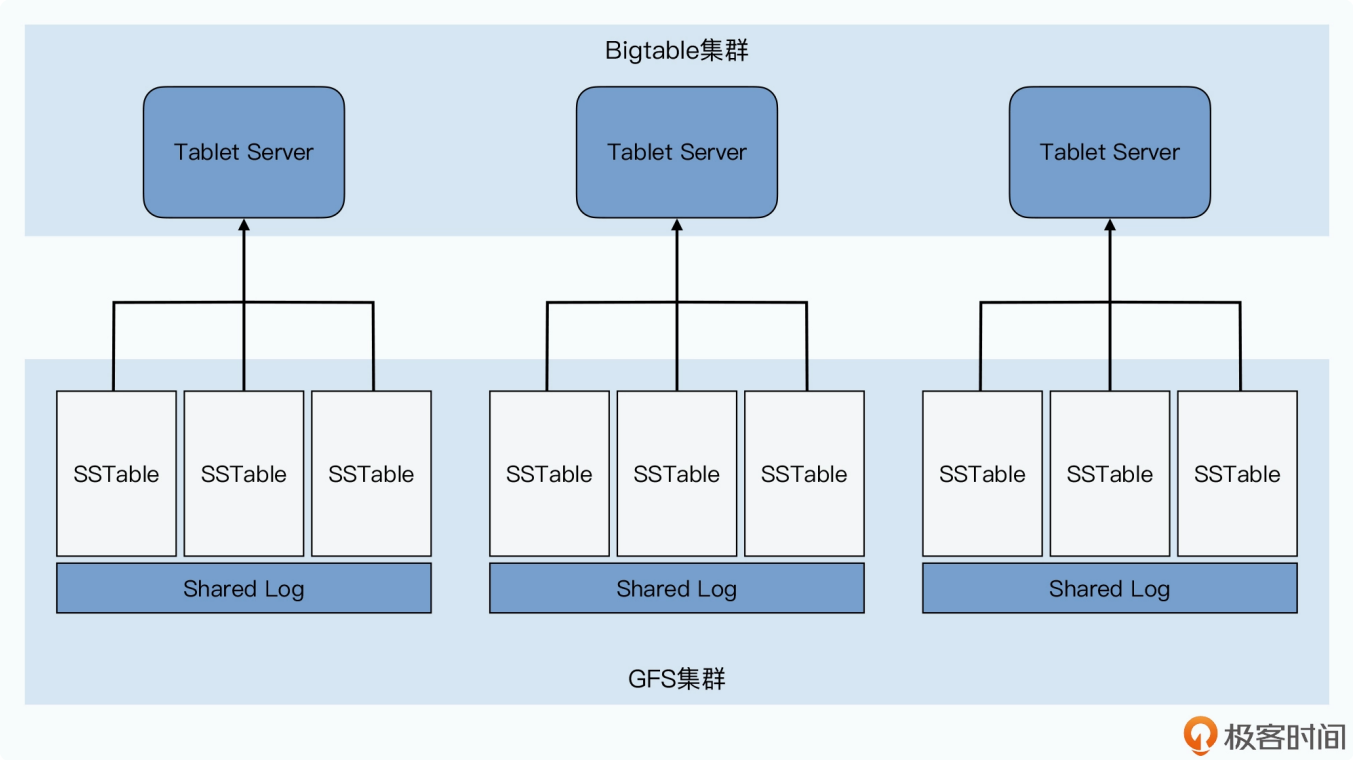

Bigtable的集群，在线服务和存储是分离的，数据存储依赖GFS
我们可以把Bigtable的进程直接部署在GFS里
但即便这样，我们也并不保障Tablet Server所服务的Tablets下的底层SSTable数据，在同一个物理服务器上

事实上，Master 一共会负责 5 项工作：

分配 Tablets 给 Tablet Server；

检测 Tablet Server 的新增和过期；

平衡 Tablet Server 的负载；

对于 GFS 上的数据进行垃圾回收（GC）；

管理表（Table）和列族的 Schema 变更，比如表和列族的创建与删除。

那看到这里你可能要问了，好像 Master 加上 Tablet Server 就足以组成 Bigtable 了，**为什么还有一个 Chubby 这个组件呢？**别着急，你接着往下看。

Bigtable 需要 Chubby 来搞定这么几件事儿：

确保我们只有一个 Master；

存储 Bigtable 数据的引导位置（Bootstrap Location）；

发现 Tablet Servers 以及在它们终止之后完成清理工作；

存储 Bigtable 的 Schema 信息；

存储 ACL，也就是 Bigtable 的访问权限。

这里面的最后两项只是简单的数据存储功能，我们就不多讲了，我们重点来看看前三项。

如果没有 Chubby 的话，我能想到最直接的集群管理方案，就是让所有的 Tablet Server 直接和 Master 通信，把分区信息以及 Tablets 分配到哪些 Tablet Server，也直接放在 Master 的内存里面。这个办法，就和我们之前在 GFS 里的办法一样。但是这个方案，也就使得 Master 变成了一个**单点故障点**（SPOF-Single Point of Failure）。当然，我们可以通过 Backup Master 以及 Shadow Master 等方式，来尽可能提升可用性。

可是这样第一个问题就来了，我们在 GFS 的论文里面说过，我们可以通过一个外部服务去监控 Master 的存活，等它挂了之后，自动切换到 Backup Master。但是，**我们怎么知道 Master 是真的挂了，还是只是“外部服务”和 Master 之间的网络出现故障了呢？**

如果是后者的话，我们很有可能会遇到一个很糟糕的情况，就是系统里面出现了两个 Master。这个时候，可能两个客户端分别认为这两个 Master 是真的，当它们分头在两边写入数据的时候，我们就会遇到**数据不一致**的问题。

那么 Chubby，就是这里的这个**外部服务**，不过 Chubby 不是 1 台服务器，而是 5 台服务器组成的一个集群，它会通过 Paxos 这样的共识算法，来确保不会出现误判。而且因为它有 5 台服务器，所以也一并解决了高可用的问题，就算挂个 1~2 台，也并不会丢数据。关于具体 Chubby 的原理和使用，我们会在后面讲解 Chubby 论文的时候专门介绍，今天就先不展开了。

为什么数据读写不需要 Master？

Chubby 帮我们保障了只有一个 Master，那么我们再来看看分区和 Tablets 的分配信息，这些信息也没有放在 Master。Bigtable 在这里用了一个很巧妙的方法，就是直接把这个信息，存成了 Bigtable 的一张 **METADATA 表**，而这张表在哪里呢，它是直接存放在 Bigtable 集群里面的，其实 METADATA 表自己就是一张 Bigtable 的数据表。

这其实有点像 MySQL 里面的 information_schema 表，也就是数据库定义了一张特殊的表，用来存放自己的元数据。不过，Bigtable 是一个分布式数据库，所以我们还要知道，这个元数据究竟存放在哪个 Tablet Server 里，这个就需要通过 Chubby 来告诉我们了。

> Bigtable 在 Chubby 里的一个指定的文件里，存放了一个叫做 **Root Tablet** 的分区所在的位置。
>
> 然后，这个 Root Tablet 的分区，是 METADATA 表的第一个分区，**这个分区永远不会分裂**。它里面存的，是 METADATA 里其他 Tablets 所在的位置。
>
> 而 METADATA 剩下的这些 Tablets，每一个 Tablet 中，都存放了用户创建的那些数据表，所包含的 Tablets 所在的位置，也就是所谓的 User Tablets 的位置。

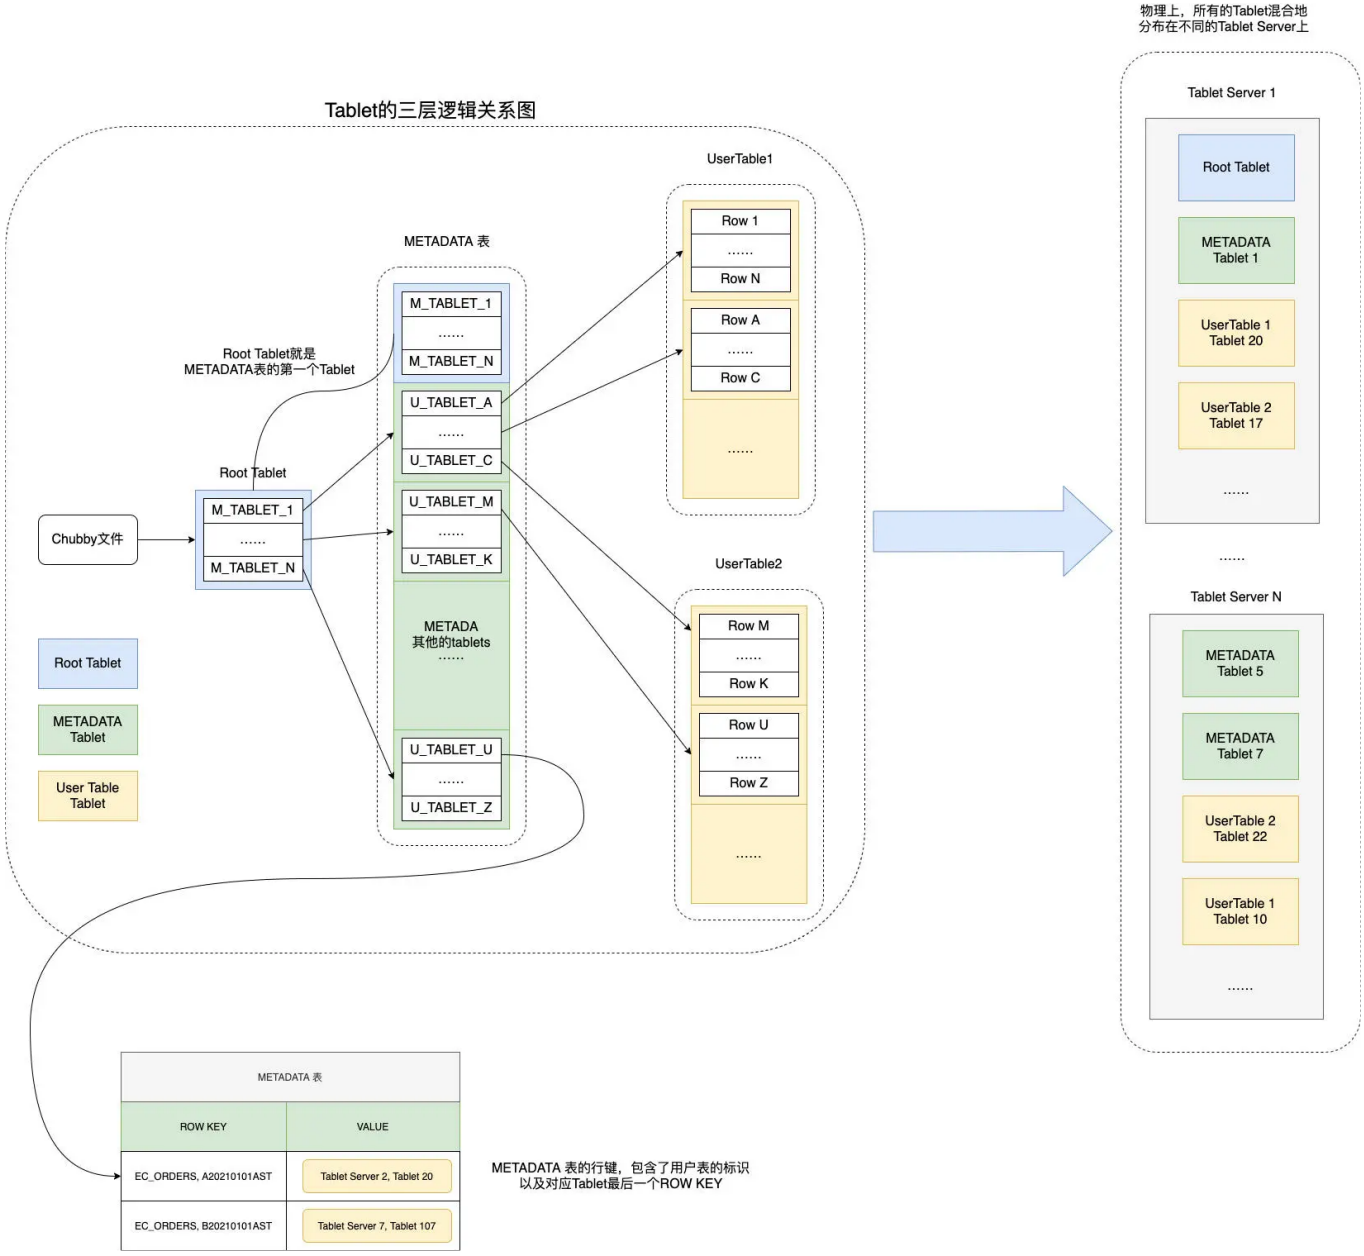

这里我们来看一个具体的 Bigtable 数据读写的例子，来帮助你理解这样一个三层结构。比如，客户端想要根据订单号，查找我们的订单信息，订单都存在 Bigtable 的 ECOMMERCE_ORDERS 表里，这张要查的订单号，就是 A20210101RST。

那么，我们的客户端具体是怎么查询的呢？

1. 客户端先去发起请求，查询 Chubby，看我们的 Root Tablet 在哪里。
2. Chubby 会告诉客户端，Root Tablet 在 5 号 Tablet Server，这里我们简写成 TS5。
3. 客户端呢，会再向 TS5 发起请求，说我要查 Root Tablet，告诉我哪一个 METADATA Tablet 里，存放了 ECOMMERCE_ORDERS 业务表，行键为 A20210101RST 的记录的位置。

4. TS5 会从 Root Tablet 里面查询，然后告诉客户端，说这个记录的位置啊，你可以从 TS8 上面的 METADATA 的 tablet 107，找到这个信息。
5. 然后，客户端再发起请求到 TS8，说我要在 tablet 107 里面，找 ECOMMERCE_ORDERS 表，行键为 A20210101RST 具体在哪里。
6. TS8 告诉客户端，这个数据在 TS20 的 tablet 253 里面。
7. 客户端发起最后一次请求，去问 TS20 的 tablet 253，问 ECOMMERCE_ORDERS 表，行键为 A20210101RST 的具体数据。
8. TS20 最终会把数据返回给客户端。

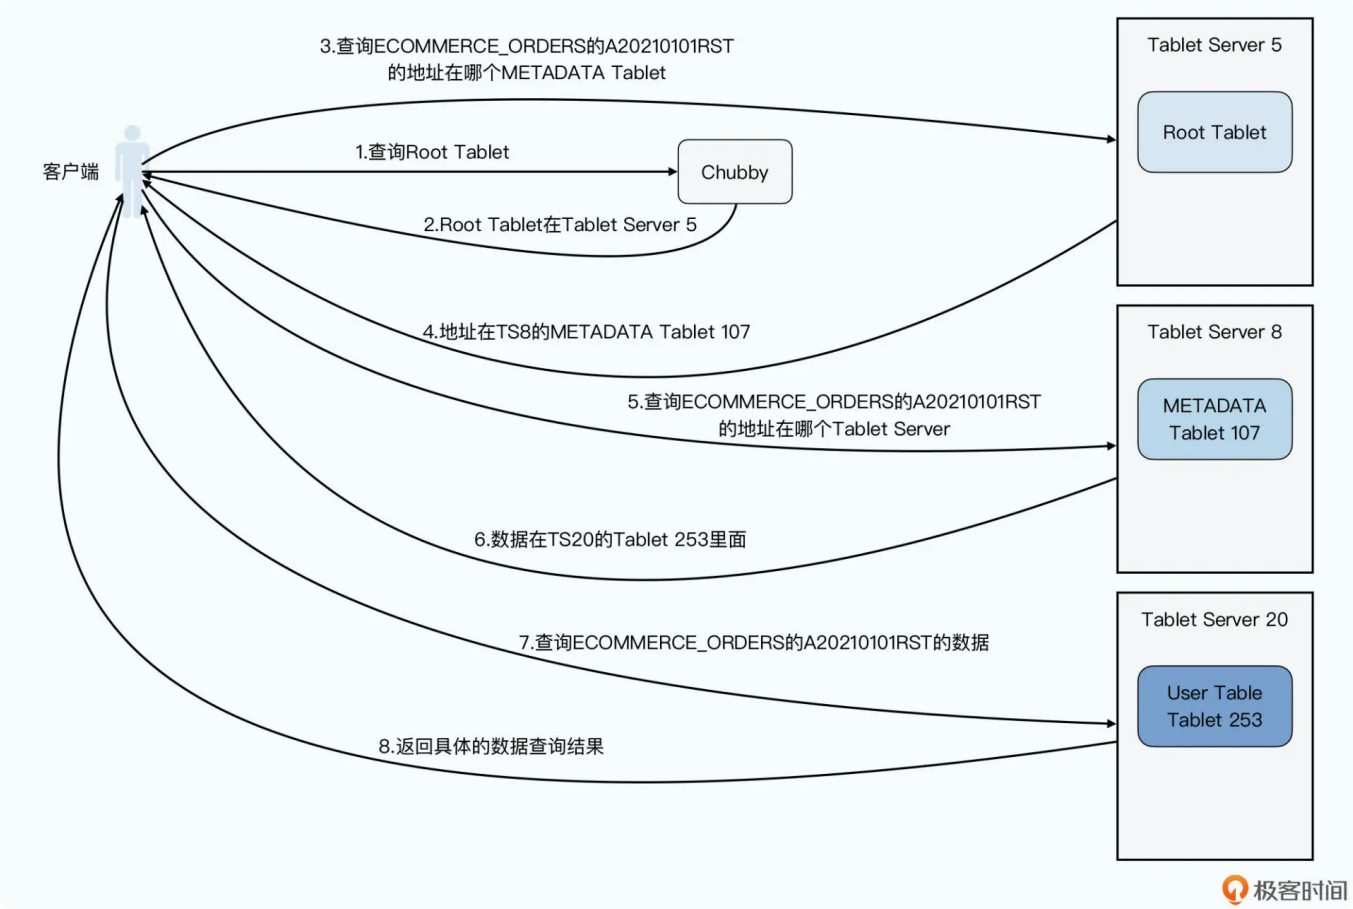

一次Bigtable的查询过程
会有3次网络请求，找到数据所在的位置
再通过1次网络请求获取到具体数据

可以看到，在这个过程里，我们用了三次网络查询，找到了想要查询的数据的具体位置，然后再发起一次请求拿到最终的实际数据。一般我们会把前三次查询位置结果缓存起来，以减少往返的网络查询次数。而对于整个 METADATA 表来说，我们都会把它们保留在**内存**里，这样每个 Bigtable 请求都要读写的数据，就不需要通过访问 GFS 来读取到了。

这个 Tablet 分区信息，其实是一个三层 Tablet 信息存储的架构，**而三层结构让 Bigtable 可以“伸缩”到足够大**。METADATA 的一条记录，大约是 1KB，而 METADATA 的 Tablet 如果限制在 128MB，三层记录可以存下大约 (128*1000)**2=2**34 个 Tablet 的位置，也就是大约 160 亿个 Tablet，肯定是够用了。

这个设计带来了一个很大的好处，就是**查询 Tablets 在哪里这件事情，尽可能地被分摊到了 Bigtable 的整个集群，而不是集中在某一个 Master 节点上。**而唯一所有人都需要查询的 Root Tablet 的位置和里面的数据，考虑到 Root Tablet 不会分裂，并且客户端可以有缓存，Chubby 和 Root Tablet 所在的 Tablet 服务器也不会有太大压力。

另外你还会发现，在整个数据读写的过程中，客户端是不需要经过 Master 的。即使 Master 节点已经挂掉了，也不会影响数据的正常读写。客户端不需要认识 Master 这个“主人”，也不依赖 Master 这个“主人”为我们提供服务。这个设计，让 Bigtable 更加“高可用”了。

而如果我们回顾前面整个查询过程，其实就很容易理解，为什么 Chubby 里面存的叫做 Bigtable 的引导位置，因为这个过程和操作系统启动的过程很类似，都是要从一个固定的位置读取信息，来获得后面的动态的信息。在操作系统里，这个是读取硬盘的第一个扇区，而在 Bigtable 里，则是 Chubby 里存放 Root Tablet 位置的固定文件。

Master 的调度者角色

的确，在单纯的数据读写的过程中不需要 Master。Master 只负责 Tablets 的调度而已，而且这个调度功能，也对 Chubby 有所依赖。我们来看一看这个过程是怎么样的：

1. 所有的 Tablet Server，一旦上线，就会在 Chubby 下的一个指定目录，获得一个和自己名字相同的**独占锁**（exclusive lock）。你可以看作是，Tablet Server 把自己注册到集群上了。
2. Master 会一直监听这个目录，当发现一个 Tablet Server 注册了，它就知道有一个新的 Tablet Server 可以用了，也就是可以分配 Tablets。
3. 分配 Tablets 的情况很多，可能是因为其他的 Tablet Server 挂了，导致部分 Tablets 没有分配出去，或者因为别的 Tablet Server 的负载太大，这些情况都可以让 Master 去重新分配 Tablet。具体的分配策略论文里并没有说，你可以根据自己的需要实现对应的分配策略。

4. Tablet Server 本身，是根据**是否还独占着 Chubby 上对应的锁，以及锁文件是否还在**，来确定自己是否还为自己分配到的 Tablets 服务。比如 Tablet Server 到 Chubby 的网络中断了，那么 Tablet Server 就会失去这个独占锁，也就不再为原先分配到的 Tablets 提供服务了。
5. 而如果我们把 Tablet Server 从集群中挪走，那么 Tablet Server 会主动释放锁，当然它也不再服务那些 Tablets 了，这些 Tablets 都需要重新分配。
6. 无论是前面的第 4、5 点这样异常或者正常的情况，都是由 Master 来检测 Tablet Server 是不是正常工作的。检测的方法也不复杂，其实就是通过**心跳**。Master 会定期问 Tablets，你是不是还占着独占锁呀？无论是 Tablet Server 说它不再占有锁了，还是 Master 连不上 Tablet Server 了，Master 都会做一个小小的测试，就是自己去获取这个锁。如果 Master 能够拿到这个锁，说明 Chubby 还活得好好的，那么一定是 Tablet Server 那边出了问题，Master 就会删除这个锁，确保 Tablet Server 不会再为 Tablets 提供服务。而原先 Tablet Server 上的 Tablets 就会变回一个未分配的状态，需要回到上面的第 3 点重新分配。
7. 而 Master 自己，一旦和 Chubby 之间的网络连接出现问题，也就是它和 Chubby 之间的会话过期了，它就会选择“自杀”，这个是为了**避免出现两个 Master 而不自知**的情况。反正，Master 的存活与否，不影响已经存在的 Tablets 分配关系，也不会影响到整个 Bigtable 数据读写的过程。

小结

好了，到了这里，相信你对整个 Bigtable 的系统架构就有一个清晰的了解了，现在我们就一起来回顾一下。

整个 Bigtable 是由 4 个组件组成的，分别是：

负责存储数据的 GFS；

负责作为分布式锁和目录服务的 Chubby；

负责实际提供在线服务的 Tablet Server；

负责调度 Tablet 和调整负载的 Master。

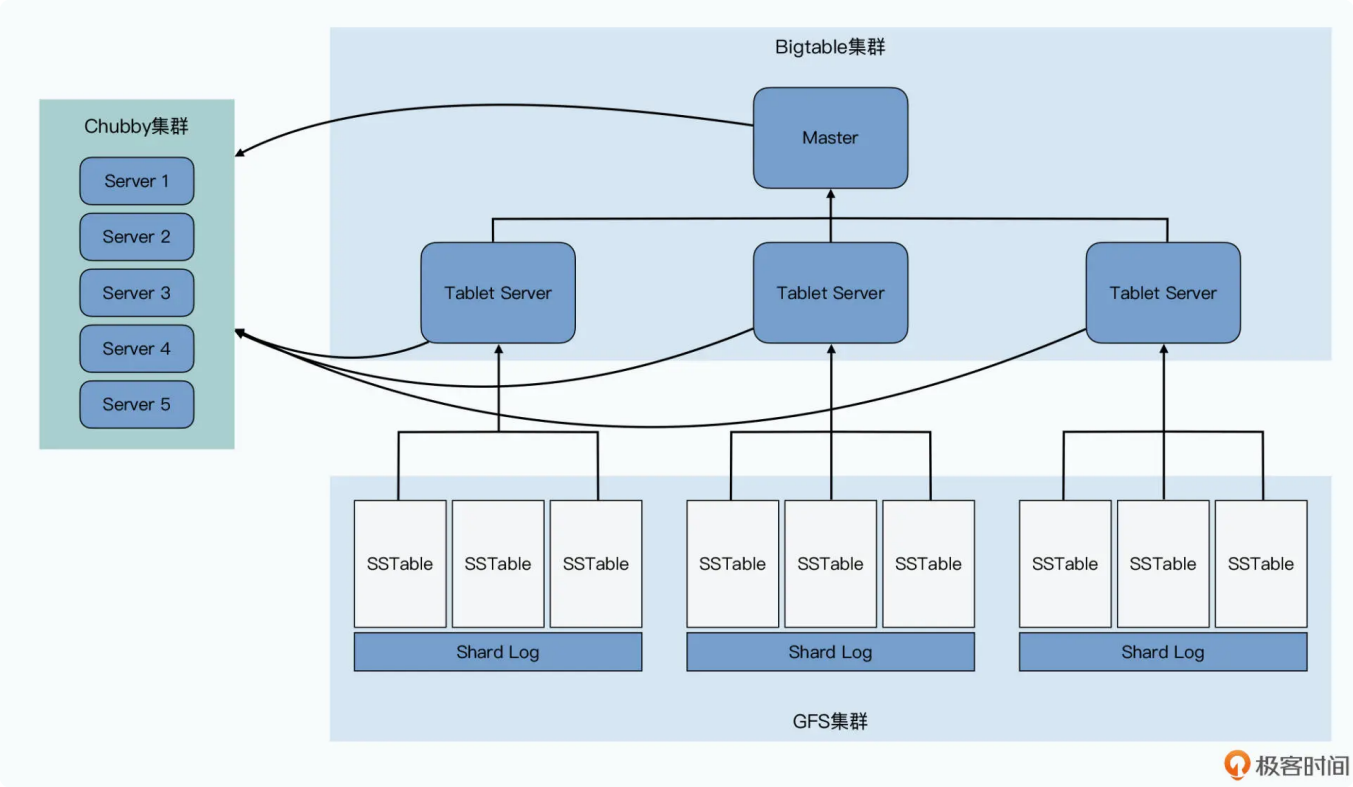

Bigtable的四个组成部分

而通过**动态区域分区**的方式，Bigtable 的分区策略需要的数据搬运工作量会很小。在 Bigtable 里，Master 并不负责保存分区信息，也不负责为分区信息提供查询服务。

Bigtable 是通过把分区信息直接做成了**三层树状结构的 Bigtable 表**，来让查询分区位置的请求分散到了整个 Bigtable 集群里，并且通过**把查询的引导位置放在 Chubby 中**，解决了和操作系统类似的“如何启动”问题。而整个系统的**分区分配工作，由 Master 完成**。通过对于 Chubby 锁的使用，就解决了 Master、Tablet Server 进出整个集群的问题。

到这里，Bigtable 的基础架构就介绍完了。不过我们还有两个非常重要的知识点需要深入探讨，一个是单个 Tablet 的底层存储和读写，具体是如何实现来做到高性能的，另一个是今天出现的神奇的 Chubby 到底是什么。接下来的两节课，我们就会一起来寻找答案。

推荐阅读

对于数据分区可以有哪些方法，《数据密集型应用系统设计》的第 6 章做了非常详尽的讲解，你可以去好好读一下。另外，对于 Bigtable 本身的论文，我也建议你多花时间去弄清楚，因为后续的 Megastore、Spanner 等等的论文，都只是 Bigtable 的升级改进而已，底层的基本原理是不变的。

思考题

Bigtable 论文里的第 7 部分“性能评估”里，你可以看到 Bigtable 在随机读数据上的性能表现并不好，无法真正做到随着节点数的增加线性增长。这是为什么呢？这个和我们今天讲的 Bigtable 的设计中的哪一个设计点相关？

分享给需要的人，Ta订阅后你可得 20 元现金奖励

生成海报并分享

赞 2 提建议

© 版权归极客邦科技所有，未经许可不得传播售卖。 页面已增加防盗追踪，如有侵权极客邦将依法追究其法律责任。

上一篇 08 | Bigtable（一）：错失百亿的Friendster

下一篇 10 | Bigtable（三）：SSTable存储引擎详解

精选留言 (11)

写留言

陈迪
2021-10-08

问老师：
10多年前的Bigable架构是否是一种符合当下潮流的“存储和计算分离”的架构？存储GFS做得够了，就用GFS单独存，前面哪个tablet压力大可以调度出来多一点。
当下则是objcet storage又便宜又可靠，不要share nothing本机再做一遍存储了，都交给object storage

展开

1

thomas
2021-10-15

老师，Bigtable 的基本数据模型 希望举个实际的数据应用场景

灰灰
2021-10-13

打卡，不是很仔细，还需要重新读。

展开

webmin
2021-10-10

思考题：
1. 随机读无法真正做到随着节点数的增加线性增长，这是为什么呢？
读取1000字节的值，需要从GFS读取一个64KB的Block，随着机器的增加1Gbps 网络带宽达到饱和，每个节点的吞吐量都有显示下降，瓶颈在网络总带宽。
2. 这个和我们今天讲的 Bigtable 的设计中的哪一个设计点相关？...

展开

在路上
2021-10-09

徐老师好，在Bigtable论文的第 7 部分“性能评估”里写道：
Each random read involves the transfer of a 64 KB SSTable block over the network from GFS to a tablet server, out of which only a single 1000-byte value is used……
Random and sequential writes perform better than random reads since each tablet server appends all incoming writes to a single commit log and uses group commit to stream th...

展开

1

吴小智

2021-10-09

想请教老师，metadata 里面具体存了什么呢？与 gfs 中文件的位置的关联的信息是怎么存的？

吴小智

2021-10-08

想请教老师，tablet 的 split 具体会做些什么？会涉及到 gfs 中数据的迁移吗？还是仅涉及到 metadata 的修改？

展开

吴小智

2021-10-08

METADATA 的一条记录，大约是 1KB，而 METADATA 的 Tablet 如果限制在 128MB，三层记录可以存下大约 (128*1000)2=234 个 Tablet 的位置，也就是大约 160 亿个 Tablet，肯定是够用了。 中 (128*1000)2=234 这个怎么理解？

展开

1

陈迪

2021-10-08

随机读，最差情况下，要网络走查元数据+从gfs读出来，gfs一读一block就是64mb，一个key value大小往往远小于这个数字。写的话就没这个问题，读内存也会快，顺序读的话key排序+ gfs支持得本来也好。相比之下，随机读显得很糟糕了

展开

那时刻

2021-10-08

Bigtable数据随机读写慢，我想到的原因是：其一是个三层 Tablet 信息存储的架构，读写有多次网络请求。其二是tablet的分裂和合并，使数据产生迁移。

展开

峰

2021-10-08

随机读最后只落在一台sever上，不能并行，再加上一次读取转换成了串行的三次读，自然相较而言是慢的。

展开